

# Drones-DT: Gerenciamento Dinâmico de Frotas de Drones Representados por Gêmeos Digitais

José Miqueias<sup>1</sup>, Lucas Silva Lopes<sup>1</sup>, Iure Fé<sup>1</sup>, Jonas Nunes<sup>1</sup>  
Luiz Fernando Bittencourt<sup>2</sup>, Juliano Wickboldt<sup>3</sup> e Francisco Airton Silva<sup>1</sup>

<sup>1</sup>Universidade Federal do Piauí – PI – Brasil

<sup>2</sup>Universidade de Campinas – SP – Brasil

<sup>3</sup>Universidade Federal do Rio Grande do Sul – RS – Brasil

{jmiqueias, lucaslopes092020, iure.fe, jonas.nunes, faps}@ufpi.edu.br  
bit@ic.unicamp.br jwickboldt@inf.ufrgs.br

**Resumo.** *Sistemas de entregas com drones têm se mostrado uma alternativa promissora para aplicações urbanas que exigem rapidez e flexibilidade operacional. Contudo, a variabilidade da demanda dificulta o dimensionamento adequado da frota, podendo resultar em subutilização de recursos ou em violações de Acordos de Nível de Serviço (SLA), especialmente relacionados ao tempo médio de entrega. Este trabalho propõe Drones-DT, uma arquitetura de Gêmeo Digital baseada em um modelo de Redes de Petri Estocásticas para o gerenciamento dinâmico de frotas de drones. O Drones-DT é continuamente sincronizado com um simulador de drones e realiza análises preditivas do tipo what-if para estimar métricas de desempenho. A partir dessas estimativas, um mecanismo de decisão orientado por SLA ajusta dinamicamente a quantidade de drones em operação. Os resultados indicam que a abordagem proposta mantém o cumprimento do SLA ao mesmo tempo em que reduz a quantidade média de drones utilizados quando comparada a estratégias estáticas.*

**Abstract.** *Drone delivery systems have proven to be a promising alternative for urban applications that require speed and operational flexibility. However, the variability of demand makes it difficult to adequately size the fleet, which can result in underutilization of resources or violations of Service Level Agreements (SLAs), especially those related to average delivery time. This work proposes a Digital Twin architecture for the dynamic management of drone fleets, based on a Stochastic Petri Net model. Drones-DT is continuously synchronized with a drone simulator and performs what-if predictive analyses to estimate performance metrics. Based on these estimates, an SLA-driven decision mechanism dynamically adjusts the number of drones in operation. The results indicate that the proposed approach maintains SLA compliance while reducing the average number of drones used when compared to static strategies.*

## 1. Introdução

O uso de veículos aéreos não tripulados, popularmente conhecidos como drones, tem se consolidado como uma alternativa promissora para operações urbanas que demandam rapidez, flexibilidade operacional e eficiência logística [Betti Sorbelli 2024]. Nesse contexto, drones vêm sendo cada vez mais empregados em serviços de entrega urbana,

como comércio eletrônico e transporte de medicamentos e alimentos, com o objetivo de reduzir tempos de atendimento e ampliar a capilaridade logística [Rejeb et al. 2023, Nurgaliev et al. 2023]. Nessas aplicações, a operação eficiente da frota é fundamental, pois impacta diretamente os indicadores de desempenho e o cumprimento de Acordos de Nível de Serviço (*Service Level Agreements – SLAs*), especialmente aqueles relacionados ao tempo médio de entrega [Lakhwani 2025].

Apesar do potencial, a gestão de frotas de drones impõe desafios significativos, em especial devido à variabilidade da demanda ao longo do tempo, caracterizada por períodos de baixa utilização intercalados com picos concentrados em horários específicos ou eventos sazonais [Betti Sorbelli 2024]. Esse comportamento dificulta o dimensionamento da frota: enquanto uma frota superdimensionada resulta em subutilização de recursos e aumento dos custos operacionais [Dinh 2024], uma frota reduzida pode comprometer o cumprimento do SLA em períodos de alta demanda, ocasionando atrasos nas entregas.

Nesse cenário, o aluguel de drones sob demanda surge como uma alternativa viável, permitindo a ampliação temporária da frota apenas quando necessário [Ahmadon and Yamaguchi 2020]. Contudo, essa estratégia requer mecanismos de tomada de decisão capazes de determinar, de forma precisa e antecipada, quando e quanto escalar a frota [Sells and Crossley 2023], considerando fatores estocásticos como a taxa de chegada de pedidos e os tempos de voo e a disponibilidade de drones.

Para lidar com o problema de decidir, sob incerteza e variabilidade de demanda, quando e quanto escalar dinamicamente a frota de drones de forma a cumprir o SLA de tempo de entrega sem incorrer em superprovisionamento, este trabalho explora o conceito de Gêmeo Digital (DT) como um sistema de controle em *loop* fechado, capaz de integrar monitoramento, simulação analítica e prescrição de ações em tempo quase real, conforme discutido por Walton et al. [Walton et al. 2024]. Embora as missões sejam independentes, o sistema é distribuído, com coleta contínua de dados e coordenação pelo DT. A proposta, denominada Drones-DT, coleta continuamente métricas do sistema físico para sincronizar um modelo virtual baseado em Redes de Petri Estocásticas (SPN), a partir do qual são realizadas análises preditivas do tipo *what-if*. Com base nessas estimativas, o Drones-DT avalia diferentes configurações de frota e toma decisões dinâmicas e autônomas de adição ou remoção de drones alugados, que são aplicadas ao sistema físico, permitindo antecipar situações de sobrecarga e manter o SLA de tempo de entrega com a menor quantidade possível de recursos.

As principais contribuições deste trabalho são:

- A proposta de uma arquitetura de Gêmeo Digital aplicada a sistemas de entregas com drones;
- O uso de um modelo baseado em Redes de Petri Estocásticas como núcleo analítico do Drones-DT;
- Um mecanismo de decisão proativo para escalonamento dinâmico da frota, orientado por SLA.

Este artigo está organizado da seguinte forma: a Seção 2 apresenta os trabalhos relacionados; a Seção 3 descreve a arquitetura do Gêmeo Digital proposto; a Seção 4 detalha o modelo SPN e as métricas adotadas; a Seção 5 valida o modelo SPN por meio da comparação com o simulador; a Seção 6 discute o estudo de caso; e a Seção 7 conclui o trabalho.

## 2. Trabalhos Relacionados

Esta seção apresenta uma análise dos principais trabalhos relacionados ao uso de Gêmeos Digitais integrados a drones, com ênfase em arquiteturas, técnicas de modelagem, abordagens de tomada de decisão e métricas adotadas. O objetivo é contextualizar o estado da arte e posicionar a proposta deste trabalho em relação às soluções existentes, destacando similaridades, diferenças e lacunas de pesquisa, especialmente no que se refere ao controle dinâmico de frotas e ao cumprimento de SLAs. A Tabela 1 mostra uma comparação dos trabalhos levantados na literatura.

**Tabela 1. Trabalhos relacionados ao uso de Gêmeos Digitais e Drones**

Trabalho	Modelo Utilizado	Abordagem	Métricas	Controle de Frota	Foco em SLA
[Filippi et al. 2023]	Gêmeo Digital (Blueprint)	Otimização bio-inspirada (Physarum) e VRP	Custos, tempo de entrega e resiliência	✓	✗
[Mohammad El-Basioni 2025]	Gêmeo Digital de Rede + RL (Aprendizado por Reforço)	Programação dinâmica e iteração de política	QoS: atraso, jitter, vazão, perda e energia	✓	✗
[Moshood et al. 2021]	Gêmeo Digital ciber-físico	Revisão sistemática da literatura	Visibilidade e eficiência da cadeia de suprimentos	✗	✗
[Lv et al. 2021]	Gêmeo Digital + CNN	Deep Learning com AlexNet aprimorada	Atraso, energia, tempo de tarefa e precisão	✓	✗
[Lakhwani 2025]	Gêmeo Digital Multiagente	Meta-heurísticas, IoT e Blockchain	Tempo, custo, carbono e conformidade	✓	✓
[Salem et al. 2024]	Gêmeo Digital integrado ao BIM	Fotogrametria, GPS e análise por IA	Progresso da obra, precisão e segurança	✗	✗
Este trabalho	Redes de Petri Estocásticas (SPN)	Análise preditiva e ajuste de frota	Tempo Médio de Missão, vazão e utilização da frota	✓	✓

O uso de Gêmeos Digitais integrados a drones tem sido amplamente investigado como uma abordagem promissora para a modernização de sistemas logísticos, industriais e de serviços críticos. Os trabalhos relacionados foram comparados segundo dimensões relevantes, incluindo papel do Gêmeo Digital, nível de autonomia da frota, técnicas de decisão empregadas, métricas avaliadas e tratamento de Acordos de Nível de Serviço.

**Modelos de Gêmeos Digitais e controle de frota.** Uma primeira distinção entre os trabalhos refere-se ao papel desempenhado pelo Gêmeo Digital. Parte da literatura emprega o Gêmeo Digital predominantemente como uma ferramenta de monitoramento, visualização e diagnóstico, sem envolvimento direto em mecanismos de controle ativo da frota. Nesse grupo, [Moshood et al. 2021] apresentam uma revisão sistemática sobre o uso de DTs na cadeia de suprimentos, destacando ganhos em transparência e eficiência logística, enquanto os drones atuam essencialmente como sensores móveis para coleta de dados.

De forma semelhante, [Salem et al. 2024] exploram a integração entre DT e BIM para gerenciamento de projetos de construção, utilizando drones para fotogrametria e inspeção visual. Em ambos os trabalhos, o DT reflete o estado do sistema físico, mas não realiza ajustes dinâmicos nas operações nem influencia diretamente o controle da frota. Em contraste, trabalhos como [Filippi et al. 2023], [Lv et al. 2021], [Mohammad El-Basioni 2025] e [Lakhwani 2025] avançam no sentido de utilizar o DT como elemento central de controle ativo e tomada de decisão, permitindo adaptações

dinâmicas no comportamento da frota. Esses estudos caracterizam uma evolução do DT de um artefato passivo de observação para um componente ativo de orquestração do sistema.

**Abordagens de decisão e métricas avaliadas.** No que diz respeito às técnicas de decisão, observa-se que trabalhos como [Filippi et al. 2023], [Lv et al. 2021] e [Mohammad El-Basioni 2025] apresentam forte predominância de abordagens baseadas em otimização heurística e aprendizado de máquina. Em particular, [Filippi et al. 2023] propõem um DT do tipo *blueprint* para redes distribuídas de saúde, combinando algoritmos bioinspirados, como Physarum, com formulações de *Vehicle Routing Problem*, visando minimizar custos, tempo de entrega e aumentar a resiliência do sistema. De forma complementar, [Lv et al. 2021] utilizam um DT integrado a redes neurais convolucionais, baseadas em uma versão aprimorada da AlexNet, para apoiar entregas rápidas de recursos médicos em cenários epidêmicos, priorizando métricas como atraso, consumo de energia, tempo de tarefa e precisão.

Já [Mohammad El-Basioni 2025] adotam um Gêmeo Digital de rede aliado ao Aprendizado por Reforço para o design conjunto de topologia, mobilidade e roteamento em FANETs, avaliando métricas clássicas de Qualidade de Serviço, como atraso, jitter, vazão, perda de pacotes e consumo de energia. Embora eficazes, os trabalhos de [Filippi et al. 2023], [Lv et al. 2021] e [Mohammad El-Basioni 2025] concentram-se majoritariamente em estratégias de otimização pontuais, fortemente dependentes de treinamento, parametrização ou heurísticas específicas, apresentando menor ênfase em modelagens formais do comportamento estocástico do sistema.

**Foco em SLA.** Outra dimensão relevante refere-se ao tratamento explícito de SLA no processo de decisão. Nos trabalhos de [Filippi et al. 2023], [Lv et al. 2021], [Mohammad El-Basioni 2025] e [Salem et al. 2024], o desempenho da frota é avaliado principalmente por meio de métricas técnicas de QoS, como atraso, consumo de energia, vazão, jitter ou perda de pacotes, tratando o SLA de forma indireta ou implícita, como uma consequência do bom desempenho médio do sistema. Uma exceção importante é o trabalho de [Lakhwani 2025], que incorpora explicitamente o cumprimento de SLA como elemento central da arquitetura com foco em orquestração e confiança, diferente deste trabalho que foca em otimização de recursos.

**Principais diferenças e posicionamento do presente trabalho.** Diferentemente das abordagens baseadas exclusivamente em aprendizado de máquina, otimização heurística ou mecanismos de fiscalização contratual, o presente trabalho utiliza SPN como núcleo analítico do Gêmeo Digital. Essa modelagem formal permite representar explicitamente o comportamento estocástico do sistema e realizar análises preditivas do tipo *what-if*. Além disso, o SLA não é tratado como um requisito externo ou métrica de validação posterior, mas como um gatilho direto para a tomada de decisão.

Com base nas análises preditivas do DT, um mecanismo de decisão orientado por SLA ajusta dinamicamente a quantidade de drones em operação, utilizando um método de busca binária para identificar a configuração mínima de frota capaz de garantir o tempo médio de missão acordado. Dessa forma, a literatura evolui de modelos de simples observação digital para sistemas de orquestração autônoma. Nesse contexto, este trabalho se posiciona ao combinar modelagem formal, análise preditiva e controle dinâmico orientado por SLA, contribuindo para o gerenciamento eficiente de frotas de drones em sistemas caracterizados por alta variabilidade de demanda.

### 3. Arquitetura do Drones-DT para Entregas com Drones

A arquitetura proposta, ilustrada na Figura 1, é organizada em dois domínios: o sistema físico de entregas com drones e o Drones-DT, que opera como um mecanismo de controle em *loop* fechado. Essa separação permite desacoplar a execução operacional das entregas da análise preditiva e da tomada de decisão, viabilizando ajustes proativos no dimensionamento da frota.

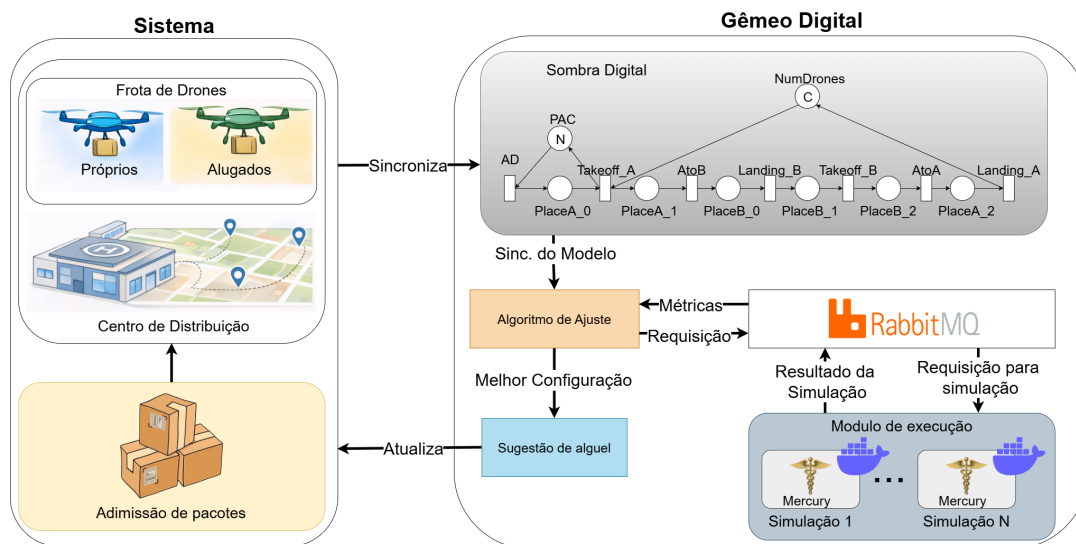


Figura 1. Arquitetura do Drones-DT para o sistema de entrega com drones.

O sistema é responsável pela execução das operações de entrega e é composto por três elementos principais: a frota de drones, o centro de distribuição e a admissão de pacotes. A frota é formada por drones próprios e drones alugados, os quais são tratados de forma homogênea do ponto de vista operacional, diferindo apenas em termos de custo e disponibilidade. Cada drone realiza missões de entrega completas, envolvendo preparação, deslocamento até o destino, operações no ponto de entrega e retorno ao centro de distribuição.

O centro de distribuição atua como o ponto de admissão e gerenciamento das requisições de entrega. Novos pedidos chegam ao sistema de acordo com um processo estocástico, representando a variabilidade natural da demanda ao longo do tempo. Esses pedidos são enfileirados e despachados à medida que drones disponíveis se tornam aptos a iniciar novas missões. Durante a operação, o sistema monitora continuamente métricas relevantes, como tempo médio de voo, vazão, tempo médio de entrega e utilização da frota. As métricas são formalmente apresentadas na Seção 4 juntamente com o modelo. Essas informações são fundamentais para caracterizar o estado atual do sistema e são periodicamente enviadas ao Gêmeo Digital por meio de um mecanismo de sincronização.

O Gêmeo Digital mantém uma representação virtual do sistema, denominada Sombra Digital, implementada por meio de um modelo SPN. Esse modelo captura o comportamento estocástico das operações de entrega, incluindo a chegada de pedidos, o despacho de drones, os tempos de voo e a conclusão das entregas. O modelo SPN é executado em contêineres, o que permite sua atualização dinâmica e sua execução contínua de forma isolada do sistema físico. As métricas coletadas do sistema real são utilizadas

para parametrizar o modelo, garantindo que a Sombra Digital permaneça sincronizada com o estado atual da operação. Dessa forma, o SPN não representa um modelo estático, mas sim uma visão atualizada do sistema em execução.

Com base na Sombra Digital sincronizada, o Drones-DT executa simulações preditivas do tipo *what-if*, avaliando diferentes configurações de frota por meio da variação do número de drones disponíveis. Cada cenário permite estimar métricas como tempo médio de entrega, vazão e utilização da frota. As estimativas são baseadas em dados recentes coletados do sistema estatisticamente semelhantes. Embora não capturem integralmente todas as variabilidades do sistema real, essas estimativas são adequadas para apoiar decisões em tempo real.

Os cenários de análise *what-if* são derivados a partir do estado atual do sistema físico, refletido no Drones-DT, e construídos por meio da modificação controlada do número de drones disponíveis, dentro de limites previamente definidos pelo operador do sistema. Dessa forma, cada cenário representa uma projeção plausível de operação futura, mantendo inalterados os demais parâmetros do sistema. Essas simulações antecipam o comportamento futuro do sistema sob condições de carga semelhantes, possibilitando a identificação de situações de sobrecarga antes que elas se manifestem no sistema físico.

Os resultados das simulações são processados por um módulo de decisão orientado por SLA, cuja função é selecionar a configuração mínima de frota capaz de garantir o cumprimento do acordo de nível de serviço para o tempo médio de entrega. Para isso, o módulo emprega um método de busca binária sobre um intervalo previamente definido de números admissíveis de drones. A cada iteração, uma configuração intermediária é avaliada por meio de uma simulação preditiva *what-if*, da qual se estima o tempo médio de entrega. Caso o SLA seja atendido, o limite superior do intervalo é reduzido; caso contrário, o limite inferior é incrementado. Esse processo converge para a menor quantidade de drones viável, reduzindo o número de simulações necessárias e tornando o método adequado para execução periódica em sistemas dinâmicos.

A configuração selecionada pelo módulo de decisão é então implantada no sistema físico, ajustando dinamicamente a quantidade de drones em operação. Esse processo fecha o loop de controle do Gêmeo Digital, no qual o sistema físico fornece dados, o Drones-DT analisa e simula cenários futuros, e as decisões resultantes são aplicadas de volta ao sistema real. Esse ciclo é executado periodicamente, permitindo que o sistema se adapte continuamente a variações abruptas de demanda.

#### **4. Modelo SPN para uma Arquitetura de Gêmeo Digital**

A análise do Gêmeo Digital proposto neste trabalho é baseado em um modelo SPN, adaptado ao contexto de entregas com drones sob demanda variável e tomada de decisão dinâmica. O modelo SPN tem como objetivo representar, de forma abstrata e estocástica, o ciclo operacional das entregas realizadas por drones, possibilitando a estimação de métricas de desempenho que subsidiam as decisões do Drones-DT. A Figura 2 ilustra a estrutura do modelo SPN, destacando seus principais componentes, incluindo lugares, transições temporizadas e marcadores de lugares. O modelo representa o fluxo completo de uma entrega, desde a chegada de um pedido até o retorno do drone ao centro de distribuição, no qual um drone faz a entrega um pacote por vez.

Os lugares do modelo representam os estados lógicos do sistema de entregas. O lugar *Pac* contém marcadores que representam a capacidade do galpão, enquanto o lugar

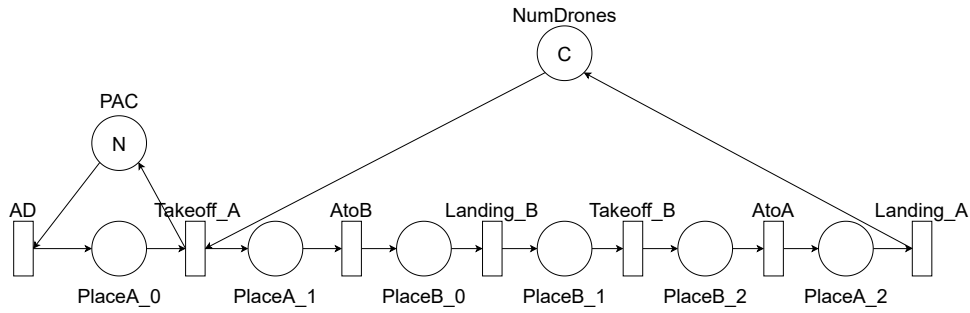


Figura 2. Modelo SPN para avaliar sistemas de entregas com drones.

PlaceA\_0 representa os pedidos aguardando atendimento. A chegada de novos pedidos é modelada por uma transição temporizada associada a um processo estocástico de chegada, refletindo a variabilidade da demanda ao longo do tempo. As descrições dos componentes do modelo podem ser observadas na Tabela 2. O lugar NumDrones representa a quantidade de drones disponíveis no sistema para iniciar novas missões. Cada marcador nesse lugar corresponde a um drone apto a realizar uma entrega. Os lugares intermediários (por exemplo, PlaceA\_1, PlaceB\_0, PlaceB\_1 e PlaceB\_2) representam as diferentes fases da missão, incluindo preparação, deslocamento até o destino, operações no ponto de entrega e retorno ao centro de distribuição.

As transições temporizadas modelam as etapas operacionais do ciclo de entrega, incluindo decolagem, voo de ida, pouso no destino, decolagem para retorno, voo de volta e pouso no centro de distribuição. Os tempos associados a essas transições são modelados por distribuições exponenciais, permitindo capturar a natureza estocástica dos tempos de voo e operação. O modelo proposto considera as transições Takeoff\_A, Landing\_B, Takeoff\_B e Landing\_A como transições do tipo *infinite server*. Essa escolha de modelagem reflete um cenário operacional em que múltiplos drones podem decolar e pousar simultaneamente, pela existência de múltiplas plataformas físicas nessas etapas. As transições associadas ao deslocamento entre os pontos A e B (por exemplo, AtoB e AtoA) também são modeladas como *infinite server*, permitindo que múltiplos drones realizem voos simultâneos, assumindo independência entre as rotas aéreas no nível de abstração adotado.

O controle da dinâmica do sistema é realizado por meio da movimentação dos marcadores entre os lugares. Quando um pedido é atendido e o ciclo de entrega é concluído, o marcador correspondente ao drone retorna ao lugar NumDrones, indicando que o recurso está novamente disponível para uma nova missão. Esse mecanismo garante a conservação do número total de drones no sistema, permitindo que o modelo represente corretamente diferentes configurações de frota. No contexto do Drones-DT, o número inicial de marcadores em NumDrones pode ser ajustado dinamicamente, refletindo a adição ou remoção de drones alugados conforme as decisões tomadas pelo sistema de controle.

No Gêmeo Digital proposto, o modelo SPN atua como a representação formal e analítica do sistema físico. Executado de forma contínua em contêineres, o modelo é periodicamente alimentado com métricas observadas no simulador de drones, como taxas de chegada de pedidos e tempos médios das etapas da missão. A partir desse estado sincronizado, o modelo SPN permite estimar métricas de desempenho, como o Tempo

Médio de Entrega e a vazão do sistema, que são utilizadas pelo Drones-DT para avaliar cenários hipotéticos (*what-if*) com diferentes tamanhos de frota. Dessa forma, o modelo SPN fornece a base preditiva necessária para a tomada de decisão proativa, viabilizando o escalonamento dinâmico de drones e a manutenção do SLA de tempo de entrega com uso eficiente de recursos.

**Tabela 2. Componentes do modelo SPN**

Tipo	Componente	Descrição
Lugares	PlaceA_0, PlaceA_1, PlaceA_2, PlaceB_0, PlaceB_1, PlaceB_2	Locais de origem e destino.
	NumDrones	Local associado à quantidade de drones disponíveis.
	Pac	Local associado à quantidade de pacotes a serem entregues.
Transições	AtoB, AtoA	Tempo de deslocamento do drone com sua distribuição exponencial (Infinite server).
	Takeoff_A, Takeoff_B	Tempo para decolagem dos drones com sua distribuição exponencial (Infinite server).
	Landing_A, Landing_B	Tempo para pouso dos drones com sua distribuição exponencial (Infinite server).
	AD	Intervalo entre as chegadas dos voos com sua distribuição Poisson (Single server).
Marcadores	C	Quantidade de drones disponíveis para missão.
	N	Número máximo de pacotes suportado pelo centro de distribuição.

#### 4.1. Métricas

Este artigo adota como métricas principais o Tempo Médio de Entrega (MMT) e a vazão do sistema, que permitem avaliar de forma objetiva o desempenho operacional do sistema de entrega com drones. O MMT representa o tempo médio necessário para que um pedido complete todo o ciclo operacional, desde sua admissão no sistema até a conclusão da entrega, sendo a métrica utilizada para verificação do cumprimento do SLA. Essa métrica incorpora os tempos de espera, deslocamento e as operações de pouso e decolagem realizadas pelos drones.

No modelo baseado em SPN, o MMT é calculado a partir da Lei de Little [Little and Graves 2008], sendo expresso pela razão entre o número médio de pedidos presentes no sistema e a vazão média de entregas concluídas. O número médio de pedidos é obtido pela soma das esperanças do número de *tokens* (marcadores de lugares) nos lugares PlaceA\_0, PlaceA\_1, PlaceB\_0, PlaceB\_1, PlaceB\_2 e PlaceA\_2, que representam os diferentes estados dos pedidos ao longo do ciclo operacional. Na Equação 1, o operador  $E\cdot$  denota a esperança matemática do número de *tokens* em regime estacionário, enquanto os *tokens* representam os pedidos em processamento no sistema.

$$\text{MMT} = \frac{E\{\#PlaceA_0\} + E\{\#PlaceA_1\} + E\{\#PlaceB_0\} + E\{\#PlaceB_1\} + E\{\#PlaceB_2\} + E\{\#PlaceA_2\}}{E\{\#PlaceA_2\}/\text{Landing}_A} \quad (1)$$

A vazão do sistema é obtida a partir do número médio de tokens no lugar

PlaceA\_2, associado às entregas concluídas no modelo SPN. A normalização pelo parâmetro Landing\_A, que representa o tempo médio das operações de pouso e decolagem, permite expressar a vazão como a taxa média de pedidos finalizados por unidade de tempo, conforme a Equação 2.

$$\text{Vazão} = \frac{E\{\#PlaceA_2\}}{\text{Landing}_A} \quad (2)$$

As simulações são conduzidas em regime estacionário, permitindo a análise do comportamento médio do sistema em equilíbrio dinâmico. As esperanças estatísticas dos lugares são obtidas por meio da ferramenta Mercury [Maciel et al. 2017], utilizada para a resolução do modelo SPN e o cálculo das métricas de desempenho. Essa abordagem possibilita avaliar o impacto da quantidade de drones disponíveis sobre o tempo médio de entrega e a vazão do sistema, fornecendo subsídios para o processo de tomada de decisão do Drones-DT. Os resultados dessas análises são apresentados e discutidos na seção de estudo de caso.

## 5. Validação do Modelo SPN Comparando o Drones-DT com o Drone Delivery Sim

Esta seção apresenta a validação do modelo SPN utilizado na análise do Drones-DT, com o objetivo de avaliar o grau de aderência entre as métricas estimadas analiticamente e aquelas observadas em um sistema de entrega por drones simulado. Para essa finalidade, foi utilizado o DroneDeliverySim, um simulador leve e orientado a eventos que modela o ciclo logístico completo de entregas ponto a ponto por drones, desde a chegada dos pacotes ao centro de distribuição até o retorno dos drones após a conclusão da missão.

O DroneDeliverySim foi originalmente proposto como uma ferramenta para análise temporal e probabilística de sistemas de entrega por drones, permitindo a parametrização das etapas da missão por meio de distribuições estatísticas, bem como a simulação de cenários em larga escala com centenas de drones operando simultaneamente. O simulador adota uma arquitetura orientada a eventos e baseada em filas, o que o torna particularmente adequado para estudos de desempenho, dimensionamento de frota e avaliação de métricas como Tempo Médio de Missão e vazão do sistema. O código-fonte do simulador é disponibilizado publicamente no repositório GitLab.<sup>1</sup>

A validação do modelo SPN é fundamental para assegurar que o Drones-DT seja capaz de representar de forma fidedigna o comportamento do sistema físico simulado, possibilitando análises preditivas confiáveis e decisões de escalonamento orientadas por SLA. O processo de validação foi conduzido por meio da comparação direta entre as métricas de MMT e vazão obtidas a partir do DroneDeliverySim e aquelas estimadas pelo modelo SPN.


Para garantir uma avaliação abrangente, foram considerados diferentes pontos de operação, representando variações na carga de pedidos e na disponibilidade de drones. Esses cenários contemplam tanto regimes de operação nominal quanto condições próximas à saturação do sistema, permitindo analisar o comportamento do modelo sob diferentes níveis de estresse operacional.

---

<sup>1</sup><https://gitlab.com/pasid3/drone-delivery-sim.git>

A validação foi conduzida no sistema de simulação configurado com uma frota fixa de 50 drones e um depósito com capacidade para até 1000 pedidos em fila. A carga de trabalho foi modelada por meio de um processo estocástico de chegadas, no qual o intervalo entre pedidos varia dinamicamente ao longo do tempo. O experimento alterna ciclicamente entre alta e baixa demanda, com o intervalo entre chegadas aumentando gradativamente de 0,58 minutos até 4 minutos, isso significa que a cada 0,58 minutos chega um pacote, em seguida, reduzindo-se novamente até o valor mínimo. Esse comportamento permite avaliar o sistema sob uma ampla faixa de regimes de carga, incluindo diferentes níveis intermediários de demanda. Os tempos operacionais dos drones foram mantidos constantes ao longo dos experimentos, sendo configurados em 0,5 minutos para decolagem, 0,5 minutos para pouso e 15 min para o tempo de voo em cada trajeto, em consonância com os parâmetros adotados no simulador.

A Figura 3 apresenta a comparação entre os valores de MMT estimados pelo modelo SPN e aqueles medidos no sistema simulado sob essa configuração. Observa-se que o modelo acompanha de forma consistente a tendência temporal do sistema, reproduzindo adequadamente os períodos de aumento do tempo médio de entrega associados aos picos de demanda, bem como a posterior recuperação do sistema quando a carga diminui. Embora pequenas discrepâncias pontuais sejam observadas, o comportamento global das curvas é estatisticamente compatível.



**Figura 3. Comparação do MMT do Drones-DT com o DroneDeliverySim.**

Para avaliar quantitativamente essa aderência, foi aplicado um teste estatístico *t* de *Student* com nível de confiança de 95%, comparando as médias do MMT do modelo e do sistema. O teste resultou em um valor-p de 0,095361, superior ao nível de significância adotado ( $\alpha = 0,05$ ). Dessa forma, não há evidências estatísticas suficientes para rejeitar a hipótese nula de igualdade entre as médias, indicando que as diferenças observadas entre o modelo e o sistema não são estatisticamente significativas. A Figura 4 apresenta a comparação entre os valores de Vazão estimados pelo modelo SPN e aqueles observados no sistema simulado. Assim como no caso do MMT, o modelo reproduz de maneira consistente o comportamento do sistema ao longo dos diferentes pontos analisados, mantendo proximidade tanto em períodos de maior quanto de menor processamento de entregas.

A validação estatística da vazão também foi realizada por meio do teste *t* de *Student*, resultando em um valor-p de 0,623770. Esse valor, significativamente superior ao nível de significância de 0,05, reforça a equivalência estatística entre os resultados do modelo e do sistema para essa métrica, confirmando que o modelo SPN captura adequadamente a dinâmica de processamento das entregas.

As discrepâncias residuais observadas podem ser atribuídas a simplificações ine-




Figura 4. Comparação da vazão do Drones-DT com o DroneDeliverySim.

rentes ao modelo, como a adoção de distribuições exponenciais para tempos de voo e atendimento, bem como a abstração de fatores ambientais e operacionais que afetam o desempenho real dos drones. No entanto, tais diferenças permanecem dentro de limites aceitáveis para o propósito do trabalho, que é fornecer estimativas rápidas e confiáveis para apoiar decisões preditivas de alocação dinâmica de drones. Com base nos resultados apresentados, conclui-se que o modelo SPN é estatisticamente consistente e suficientemente preciso para representar o sistema de entregas com drones analisado. Dessa forma, o modelo mostra-se adequado para atuar como motor de inferência do Drones-DT, viabilizando análises *what-if* e decisões proativas de escalonamento da frota, mantendo o SLA de tempo de entrega mesmo em cenários de alta variabilidade de demanda.


## 6. Estudo de Caso Utilizando o Modelo SPN Validado

Esta seção apresenta um estudo de caso destinado a avaliar a efetividade do Drones-DT proposto no gerenciamento dinâmico de frotas de drones para serviços de entregas sob demanda variável. O objetivo central é analisar se a abordagem baseada em Gêmeos Digitais é capaz de manter o Acordo de Nível de Serviço de tempo médio de entrega, ao mesmo tempo em que reduz a quantidade média de drones utilizados quando comparada a estratégias estáticas de dimensionamento. O experimento considera um sistema de entregas com drones submetido a uma carga de pedidos variável ao longo do tempo, de forma a representar flutuações típicas observadas em aplicações reais, como horários de pico e períodos de baixa demanda. O sistema é configurado com um centro de distribuição que dispõe de uma frota própria inicial de 30 drones, podendo alugar dinamicamente até 70 drones adicionais, totalizando no máximo 100 drones em operação.

A carga de trabalho é modelada por meio de um processo de chegada estocástico, no qual o intervalo entre chegadas de pedidos (AD) varia ao longo do tempo entre 0,4 minutos e 8,33 minutos. Esse intervalo distinto em relação ao experimento de validação foi adotado para representar cenários mais acentuados de variação de demanda, permitindo avaliar a capacidade do Drones-DT de reagir a mudanças mais abruptas na carga do sistema. O SLA adotado estabelece um limite máximo aceitável para o MMT, representado nos gráficos por uma linha de referência constante. Foram avaliadas três estratégias distintas: (i) Frota Estática com 54 drones, configurada para operar próxima ao limiar inferior de atendimento do SLA; (ii) Frota Estática com 55 drones, uma configuração mais conservadora, garantindo maior margem de segurança para o cumprimento do SLA; e (iii) Drones-DT, no qual a quantidade de drones em operação é ajustada dinamicamente com base em análises preditivas realizadas pelo modelo SPN. Configurações com quantidades

inferiores a 54 drones não foram consideradas viáveis, pois não atenderam ao SLA ao longo do experimento.


No caso do Drones-DT, o ciclo de decisão é executado periodicamente a cada 25 minutos. A cada ciclo, o DT coleta métricas do simulador de drones, sincroniza o modelo SPN, executa simulações do tipo *what-if* e decide pela adição ou remoção de drones alugados, buscando a configuração mínima necessária para garantir o cumprimento do SLA. A Figura 5 ilustra a evolução do número de drones ao longo do tempo para as três estratégias analisadas. As estratégias estáticas mantêm valores constantes de 54 e 55 drones durante todo o experimento. Esses valores foram definidos a partir de experimentos preliminares, nos quais se observou que uma frota com 54 drones representa o menor dimensionamento capaz de atender parcialmente ao SLA, enquanto a configuração com 55 drones corresponde ao menor valor que garante seu cumprimento contínuo ao longo do período analisado. Dessa forma, a diferença de apenas um drone evidencia a alta sensibilidade do sistema ao dimensionamento da frota em regimes próximos à saturação. Em contraste, o Drones-DT ajusta dinamicamente a frota, evitando a superprovisão observada nas estratégias estáticas. Embora eficaz, essa comparação não inclui estratégias dinâmicas simples, cuja avaliação frente ao Drones-DT é deixada como trabalho futuro.



**Figura 5. Utilização de drones em relação ao tempo.**

Observa-se que o Drones-DT opera, na maior parte do tempo, com uma frota significativamente inferior às estratégias estáticas, recorrendo a incrementos pontuais apenas quando necessário para evitar violações do SLA. Ao longo de todo o experimento, a quantidade média de drones utilizada pelo Drones-DT foi de 39,47 drones. Em comparação com a estratégia estática mais conservadora (55 drones), isso representa uma economia média de 15,53 drones ao longo do tempo, evidenciando uma redução expressiva no uso de recursos. A Figura 6 apresenta o comportamento do Tempo Médio de Entrega ao longo do tempo para as três estratégias, considerando uma média móvel de 25 minutos. A linha tracejada indica o limite máximo imposto pelo SLA. Os resultados mostram que a estratégia com 54 drones opera próxima ao limiar do SLA e apresenta episódios pontuais de violação durante períodos de pico de demanda. A estratégia com 55 drones mantém o MMT consistentemente abaixo do limite, porém à custa de maior utilização de recursos. Por outro lado, o Drones-DT mantém o MMT dentro dos limites estabelecidos pelo SLA durante todo o experimento, mesmo operando com uma frota média significativamente menor.

Esse resultado evidencia a capacidade do Drones-DT de antecipar situações de sobrecarga por meio de simulações preditivas, ajustando a frota de forma proativa antes que atrasos se manifestem no sistema real. A análise conjunta dos resultados demonstra



**Figura 6. Tempo médio de missão em relação ao tempo.**

que o Drones-DT alcança um equilíbrio eficiente entre desempenho e economia de recursos. Enquanto abordagens estáticas precisam ser superdimensionadas para garantir o SLA em cenários de pico, o DT consegue identificar automaticamente o ponto mínimo de operação segura, ajustando dinamicamente a quantidade de drones alugados.

A economia média de 15,53 drones ao longo do tempo representa uma redução significativa nos custos operacionais, especialmente em cenários de alta variabilidade de demanda, reforçando a viabilidade do uso de Gêmeos Digitais baseados em modelos formais para o gerenciamento preditivo de sistemas de entregas com drones e o cumprimento de SLAs com uso racional de recursos. Por outro lado, a abordagem implica maior complexidade e custos computacionais em relação a estratégias estáticas, associados à execução contínua do modelo e ao ciclo de decisão, os quais, embora não quantificados neste trabalho, são amortizados pela periodicidade das decisões e pela rapidez das estimativas fornecidas pelo modelo SPN.

## 7. Conclusão

Este trabalho apresentou o Drones-DT, uma arquitetura de Gêmeo Digital para o gerenciamento dinâmico de frotas de drones em sistemas de entregas urbanas, com foco no cumprimento de SLA relacionados ao tempo médio de entrega. A proposta integra um modelo baseado em SPN como núcleo analítico, permitindo representar o comportamento estocástico do sistema e apoiar a tomada de decisão por meio de análises preditivas. Os resultados de validação demonstraram que o modelo SPN é estatisticamente consistente em relação ao simulador de drones, reproduzindo adequadamente métricas como MMT e vazão. No estudo de caso, o Drones-DT ajustou dinamicamente a frota conforme a variação da demanda, mantendo o SLA ao longo de todo o período analisado e operando com uma quantidade média significativamente menor de drones quando comparado a estratégias estáticas, evidenciando ganhos em eficiência operacional. Esses resultados indicam que Gêmeos Digitais baseados em modelos formais constituem uma alternativa eficaz para o gerenciamento preditivo de sistemas de entregas com drones, especialmente em cenários de alta variabilidade de demanda. Como trabalhos futuros, pretende-se estender a arquitetura proposta para considerar métricas adicionais e mais detalhamento, como consumo energético, custo operacional e condições meteorológicas.

## Agradecimentos

Este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo 2021/00199-8, CPE SMARTNESS.

## Referências

- Ahmadon, M. A. B. and Yamaguchi, S. (2020). Drone fleet rental decision support based on iterative resource-constrained scheduling. In *2020 IEEE 9th Global Conference on Consumer Electronics (GCCE)*, pages 227–230. IEEE.
- Betti Sorbelli, F. (2024). Uav-based delivery systems: A systematic review, current trends, and research challenges. *Journal on Autonomous Transportation Systems*, 1(3):1–40.
- Dinh, Q. M. (2024). Utilizing unmanned aerial vehicles in commerce and managing supply chains-a literature review.
- Filippi, G., Basu, T., Patelli, E., Vasile, M., and Fossati, M. (2023). A digital twin model for drone based distributed healthcare network. In *Proceedings of the 33rd European Safety and Reliability Conference, Southampton, UK*, pages 3–7.
- Lakhwani, T. S. (2025). Integrating 5pl frameworks with drone-based last-mile delivery: A model for future-ready logistics. *Transportation Development Research*, 3(1):27–45.
- Little, J. D. and Graves, S. C. (2008). Little’s law. In *Building intuition: insights from basic operations management models and principles*, pages 81–100. Springer.
- Lv, Z., Chen, D., Feng, H., Zhu, H., and Lv, H. (2021). Digital twins in unmanned aerial vehicles for rapid medical resource delivery in epidemics. *IEEE Transactions on Intelligent Transportation Systems*, 23(12):25106–25114.
- Maciel, P., Matos, R., Silva, B., Figueiredo, J., Oliveira, D., Fé, I., Maciel, R., and Dantas, J. (2017). Mercury: Performance and dependability evaluation of systems with exponential, expolynomial, and general distributions. In *2017 IEEE 22nd Pacific Rim international symposium on dependable computing (PRDC)*, pages 50–57. IEEE.
- Mohammad El-Basioni, B. M. (2025). Data-driven joint routing, topology, and mobility design for fanet systems using a digital twin approach. *Journal of Electrical Systems and Information Technology*, 12(1):1.
- Moshood, T. D., Nawansir, G., Sorooshian, S., and Okfalisa, O. (2021). Digital twins driven supply chain visibility within logistics: A new paradigm for future logistics. *Applied System Innovation*, 4(2):29.
- Nurgaliev, I., Eskander, Y., and Lis, K. (2023). The use of drones and autonomous vehicles in logistics and delivery. *Logistics and Transport*, 57.
- Rejeb, A., Rejeb, K., Simske, S. J., and Treiblmaier, H. (2023). Drones for supply chain management and logistics: a review and research agenda. *International Journal of Logistics Research and Applications*, 26(6):708–731.
- Salem, T., Dragomir, M., and Chatelet, E. (2024). Strategic integration of drone technology and digital twins for optimal construction project management. *Applied Sciences*, 14(11):4787.
- Sells, B. E. and Crossley, W. A. (2023). Optimization and decision-making framework for small unmanned aircraft systems fleet design. *Journal of Aircraft*, 60(4):981–994.
- Walton, R. B., Ciarallo, F. W., and Champagne, L. E. (2024). A unified digital twin approach incorporating virtual, physical, and prescriptive analytical components to support adaptive real-time decision-making. *Computers & Industrial Engineering*, 193:110241.